

upna

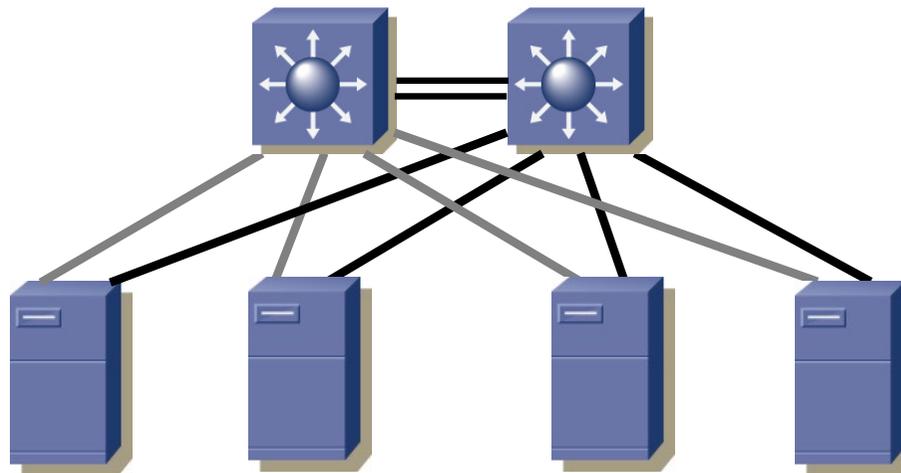
Universidad Pública de Navarra  
Nafarroako Unibertsitate Publikoa

Redes de Nueva Generación  
*Área de Ingeniería Telemática*

# NICs Ethernet para servidor

# Requerimientos

- Soporte de algún tipo de agregación de interfaces
  - Gestionable a nivel de usuario
  - O de sistema operativo
- Alto rendimiento
  - Arquitectura PC limitada para altas tasas de paquete/s
- Virtualización
  - Soporte eficiente de VMs en el host (más adelante)
- Almacenamiento
  - Integración con almacenamiento en red (más adelante)



upna

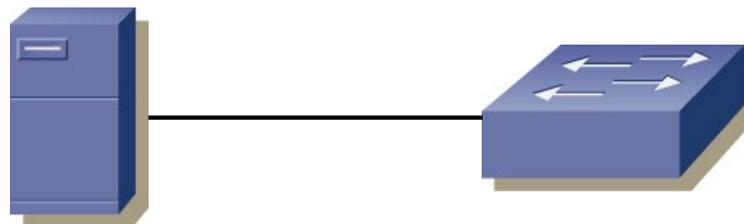
Universidad Pública de Navarra  
Nafarroako Unibertsitate Publikoa

**Redes de Nueva Generación**  
*Área de Ingeniería Telemática*

# Server multihoming

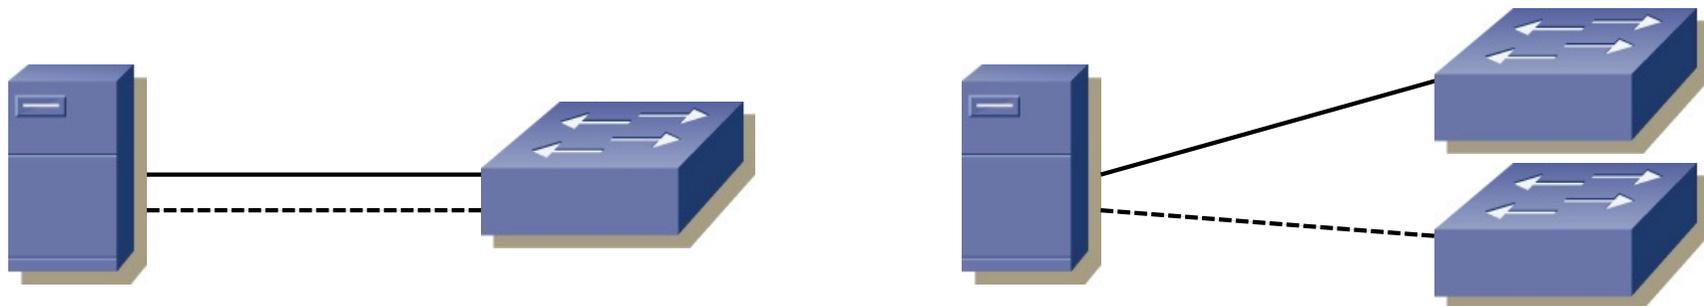
# Server multihoming

- *NIC teaming / bonding / aggregation*
- Un servidor conectado a un conmutador presenta puntos únicos de fallo: la NIC, el cable, el conmutador
- Estas soluciones requieren colaboración del driver y normalmente también del sistema operativo
- Tenemos varias mejoras posibles (con una segunda o más NICs)
- (...)



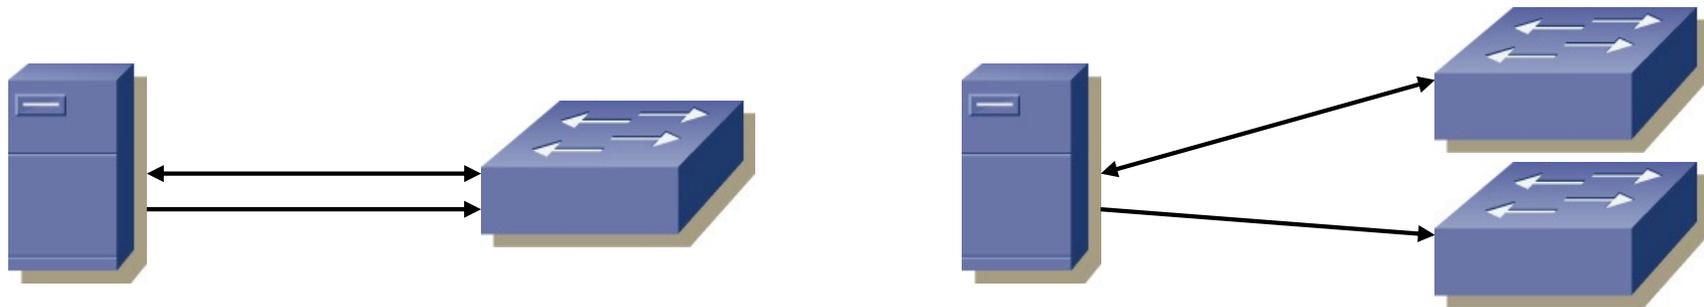
# Server multihoming

- Un segundo enlace, modo activo-pasivo
  - Si falla el primero (la NIC, el conmutador o el cable) se activa el segundo con la misma dirección MAC e IP
  - Se desaprovecha el segundo enlace



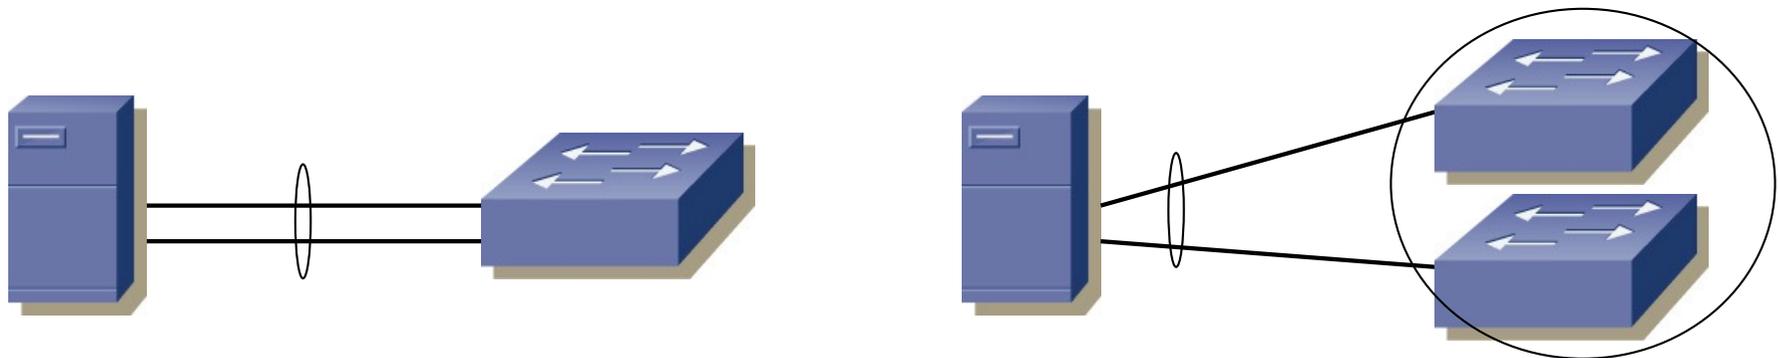
# Server multihoming

- Un segundo enlace, modo activo-pasivo
- O se usan los dos enlaces para transmitir pero solo se recibe por uno
- Cada interfaz suele enviar con diferente dirección MAC origen para no tener *MAC flapping* en el conmutador



# Server multihoming

- Un segundo enlace, modo activo-pasivo
- O se usan los dos enlaces para transmitir pero solo se recibe por uno
- O se forma un LAG (802.3ad / 802.1AX)
  - Permite usar la capacidad de ambos enlaces
  - Normalmente requiere colaboración por parte del switch
  - Si se quiere redundancia de switch hay que hacer una agregación en la que un extremo son 2 conmutadores



upna

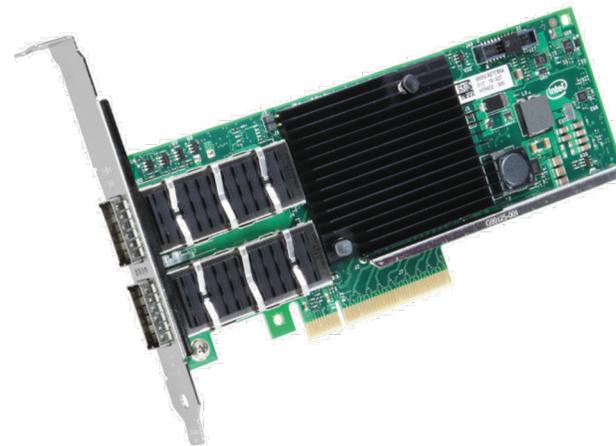
Universidad Pública de Navarra  
Nafarroako Unibertsitate Publikoa

**Redes de Nueva Generación**  
*Área de Ingeniería Telemática*

# Alto rendimiento

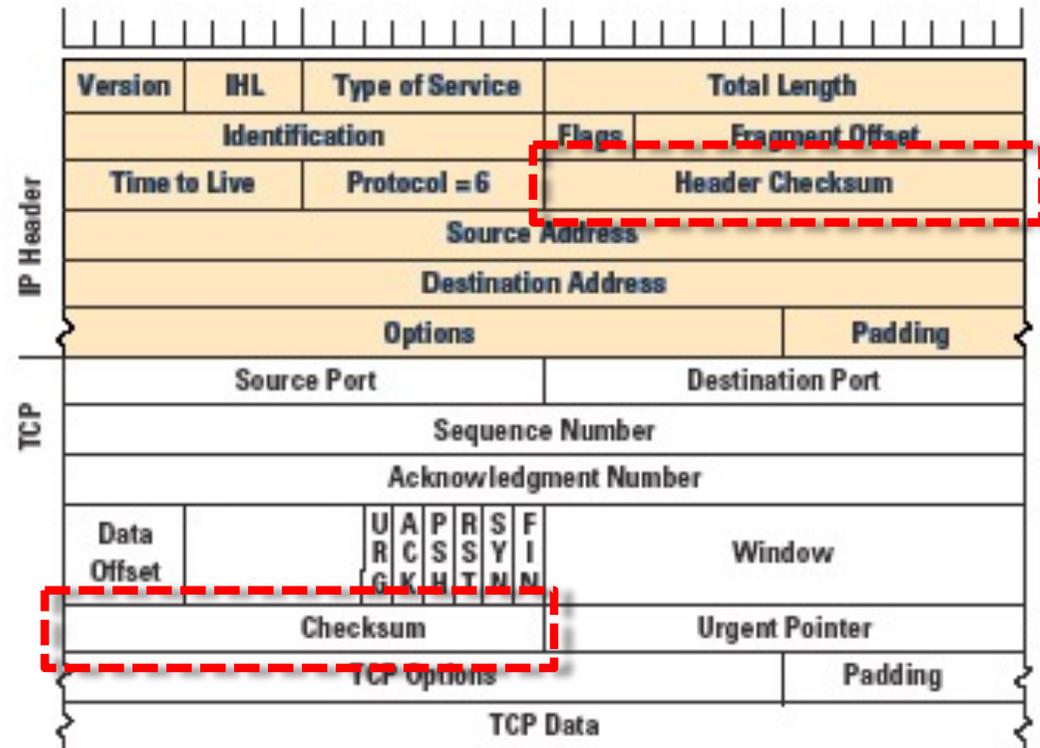
# Tareas en la NIC

- Por un enlace 10GE pueden llegar en 1 segundo más de 14 millones de tramas de 64 bytes
- Eso da a la CPU unos 67ns para procesar cada una
- Las CPUs tienen serios problemas para procesar en ese tiempo cabeceras TCP/IP
- Una NIC puede incluir electrónica para llevar a cabo ciertas tareas de TCP/IP descargando a la CPU
- La NIC puede incluir ASICs, Network Processors o un procesador con un sistema operativo de tiempo real
- A 400Gbps una trama cada 1,67ns lo cual está en el rango de los mejores tiempos de acceso a memoria



# Checksum offload

- La NIC descarga del cálculo a la CPU
- En transmisión y recepción
- Checksum IP (v4 y v6), UDP y TCP

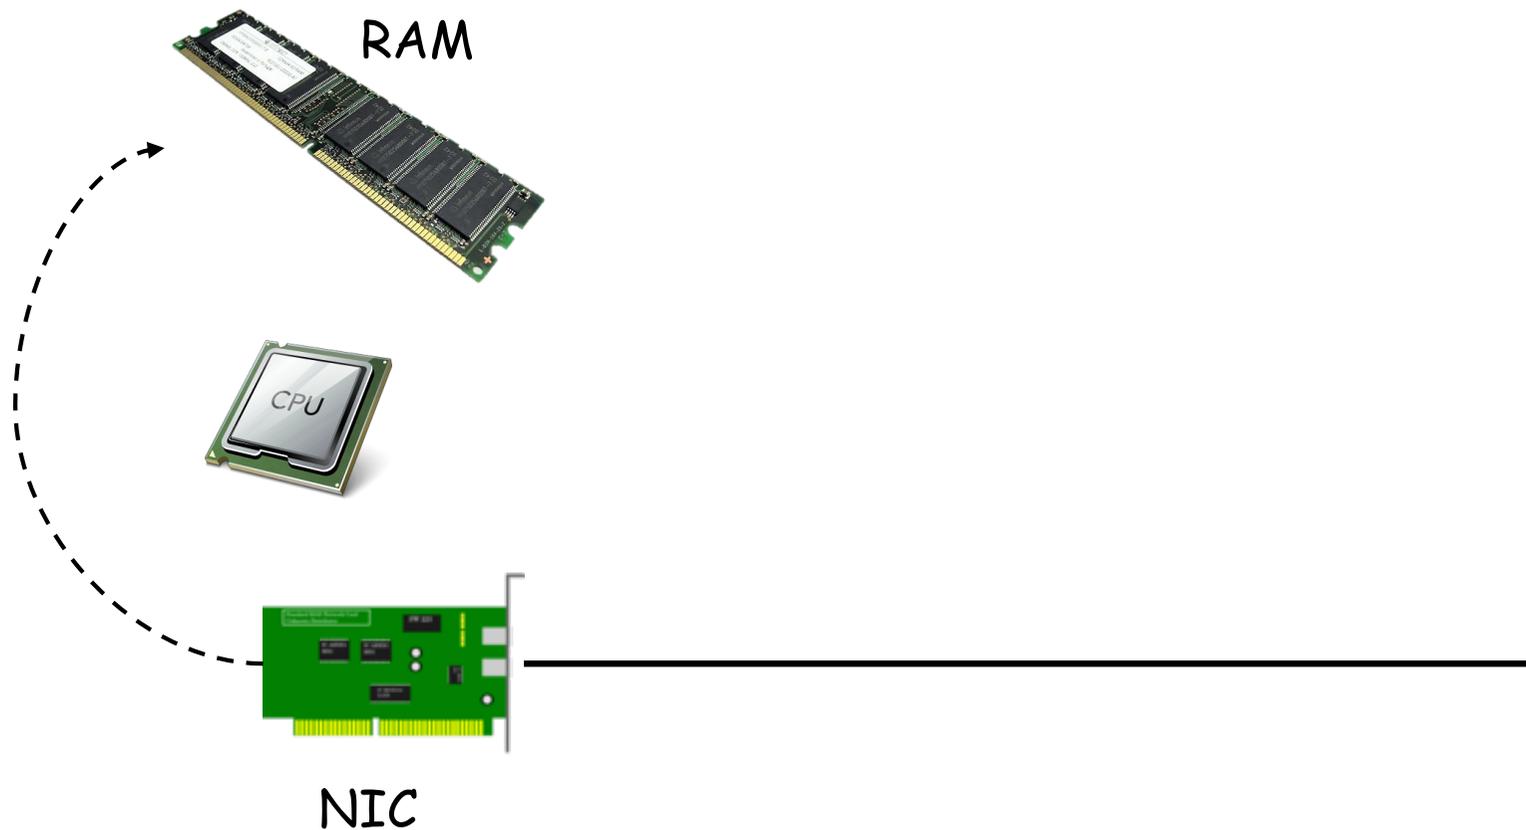


# Integración en el bus

- Coalescencia de interrupciones
  - Las NICs solían generar una interrupción por paquete
  - Alto coste para la CPU
  - Por ejemplo los mainframes tienen CPUs dedicadas a atender I/O
  - La coalescencia hace que la NIC genere una interrupción para un grupo de paquetes en vez de por cada uno
  - También puede hacer *polling* la NIC

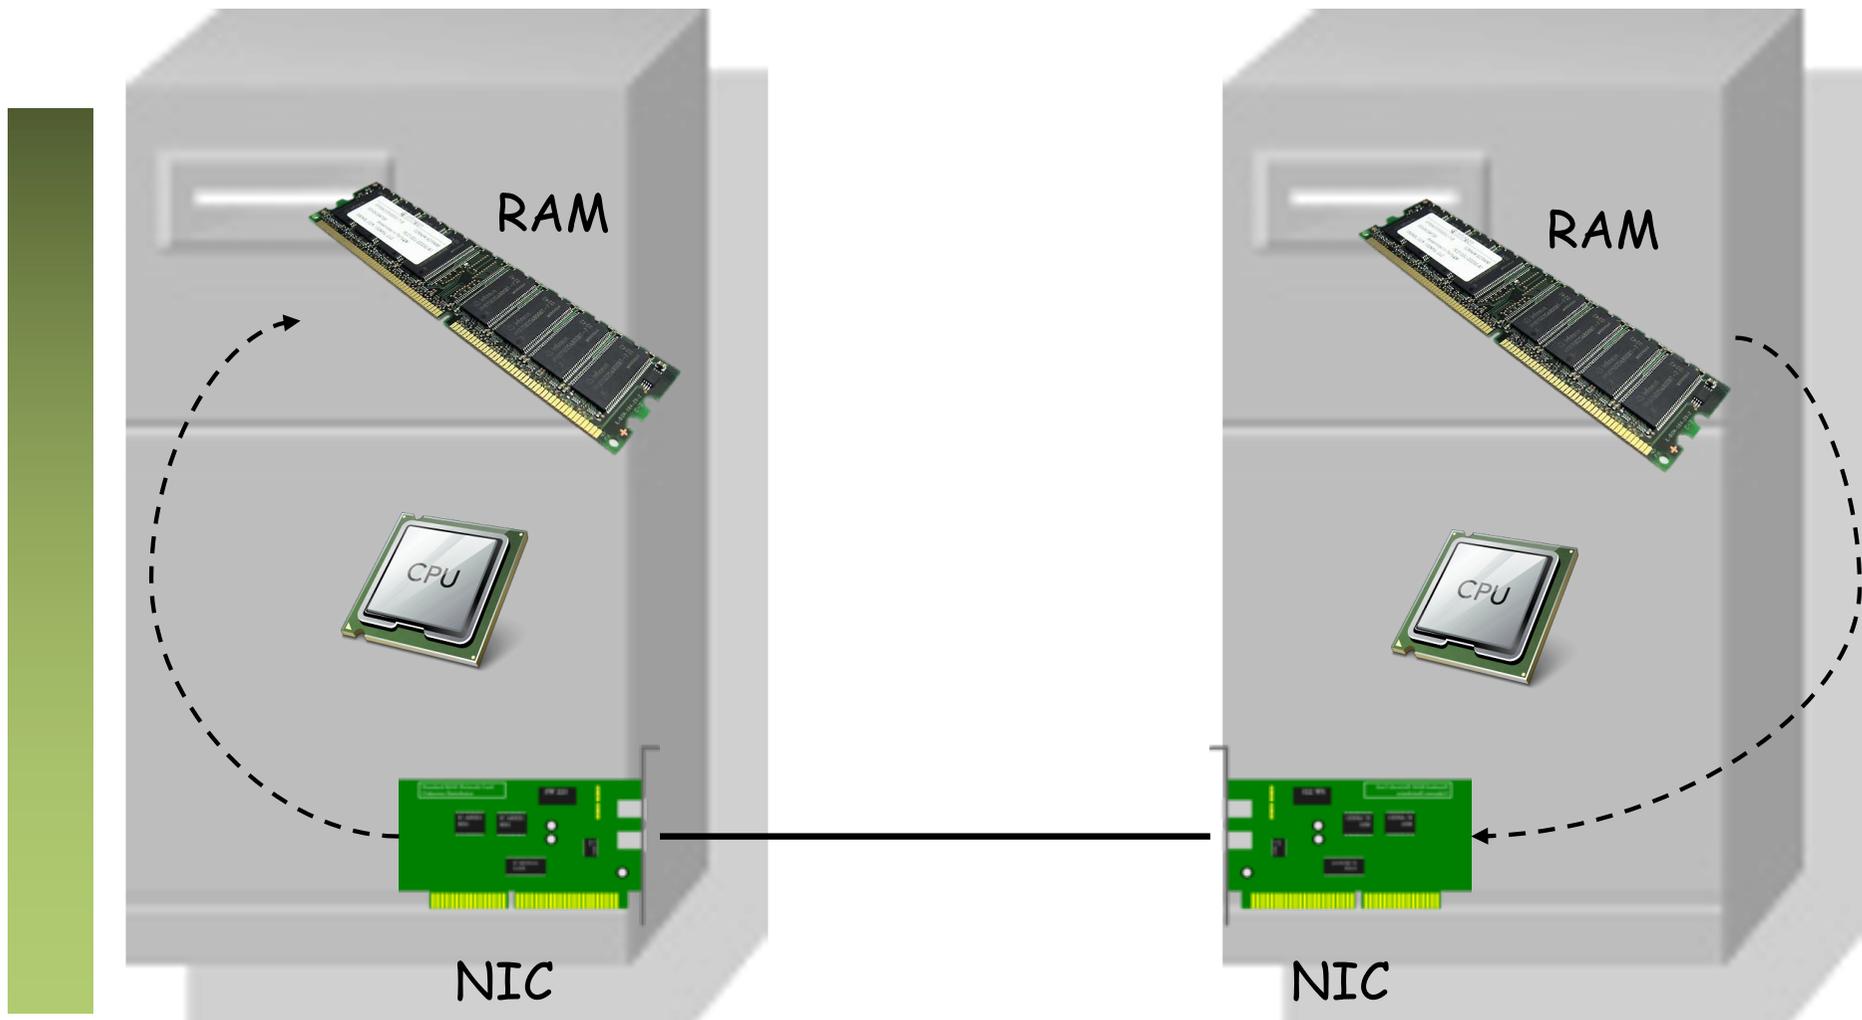
# Integración en el bus

- DMA
  - *Direct Memory Access*
  - Transferencia desde la NIC a memoria sin requerir a la CPU



# RDMA

- Remote Direct Memory Access
- Copias entre RAM de hosts diferentes sin involucrar a la CPU
- Latencia de pocos microsegundos



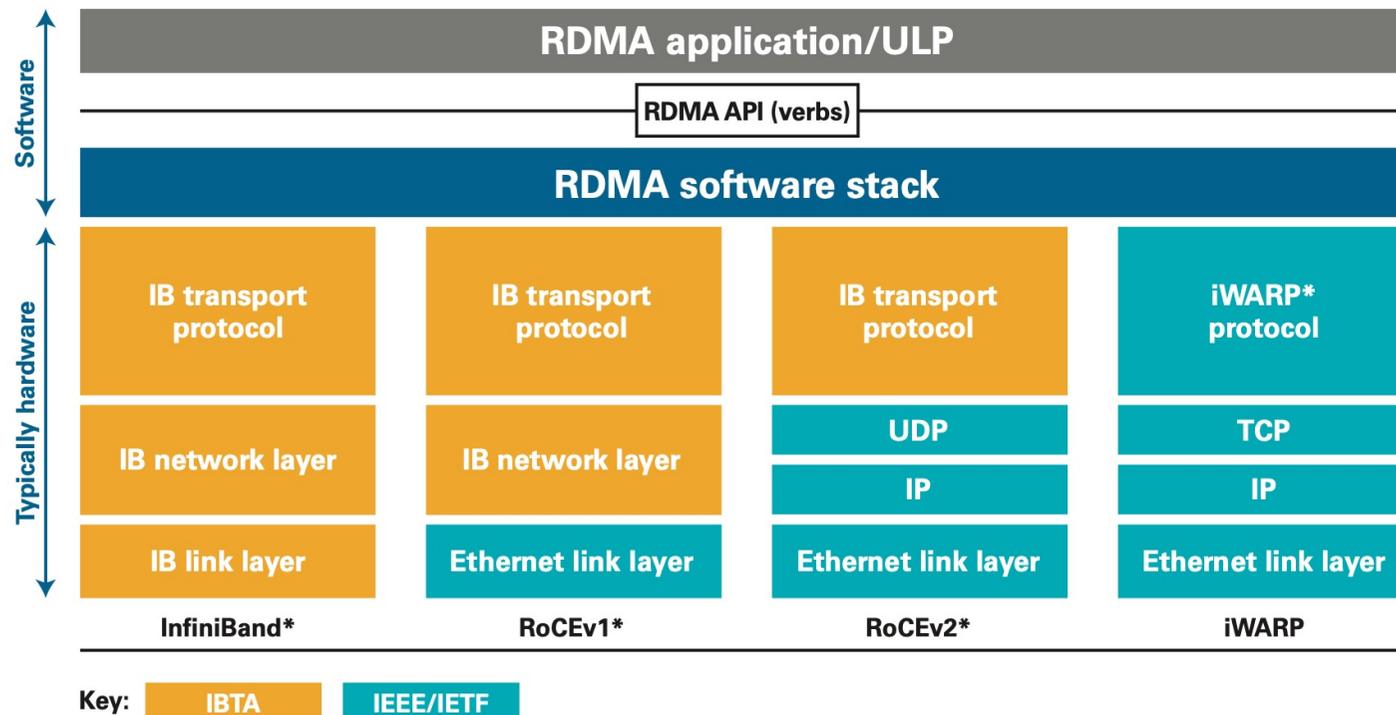
# RDMA

## iWARP

- RFCs 5040, 5041, 5044
- Sobre TCP o SCTP

## RoCE

- RDMA over Converged Ethernet (DCB, Data Center Bridging)
- RoCE v1 sobre Ethernet, v2 sobre UDP
- RoCE v1 mecanismos de control de flujo y congestión de DCB
- RoCE v2 emplea control de congestión basado en ECN



# Jumbo frames

- Tramas Ethernet con MTU superior a 1500bytes
- No están estandarizadas, la MTU estándar sigue siendo de 1500bytes
- Motivos para limitarlo
  - NICs tenían memoria limitada
  - Se quería limitar el tiempo que una estación tenía capturado el medio transmitiendo
  - El CRC es menos efectivo cuanto más grande es la trama
- Hoy en día no son problemas reales:
  - Decenas o centenares de Megabytes en la NIC
  - No tenemos medio compartido (ni coaxial ni hubs)
  - El CRC de Ethernet soporta más de 11 Kbytes de trama



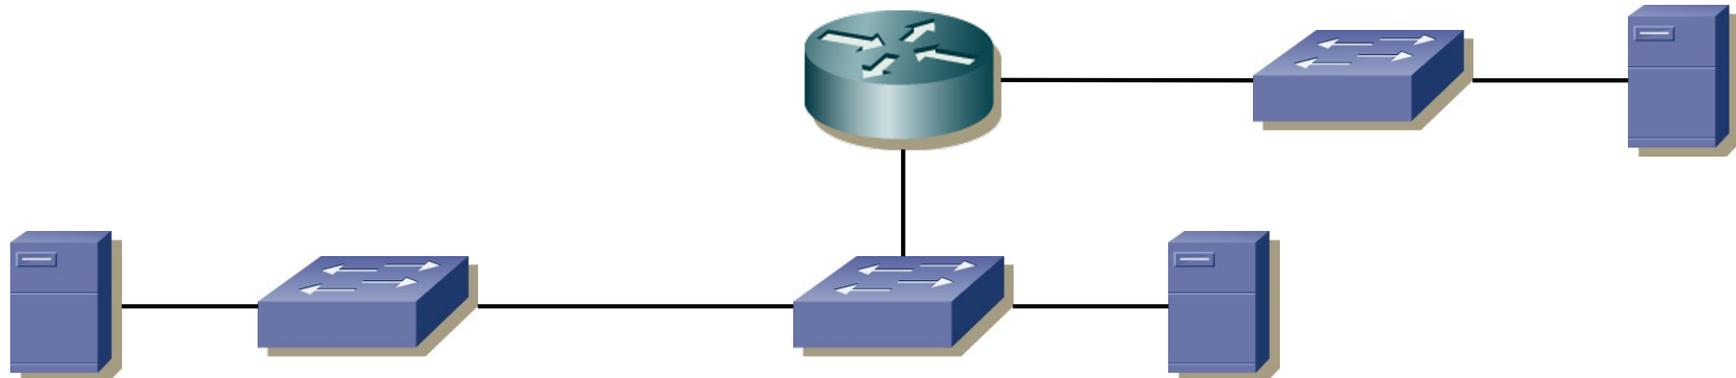
# Jumbo frames

- Diversos estándares han ido aumentando el tamaño máximo de la trama (802.1Q, 802.1ad, MPLS, FCoE, etc)
- A estas últimas en ocasiones se las llama “Baby Giant”
- Jumbo frames suelen estar cerca de los 9 Kbytes (que se puedan transportar bloques de datos de 8Kbytes + encapsulados varios)
- ¿Positivo?
  - Cuanto más grandes menor ratio de cabeceras y menos interrupciones
  - Menos carga de procesamiento de cabeceras en equipos de red y hosts
- ¿Negativo?
  - (...)



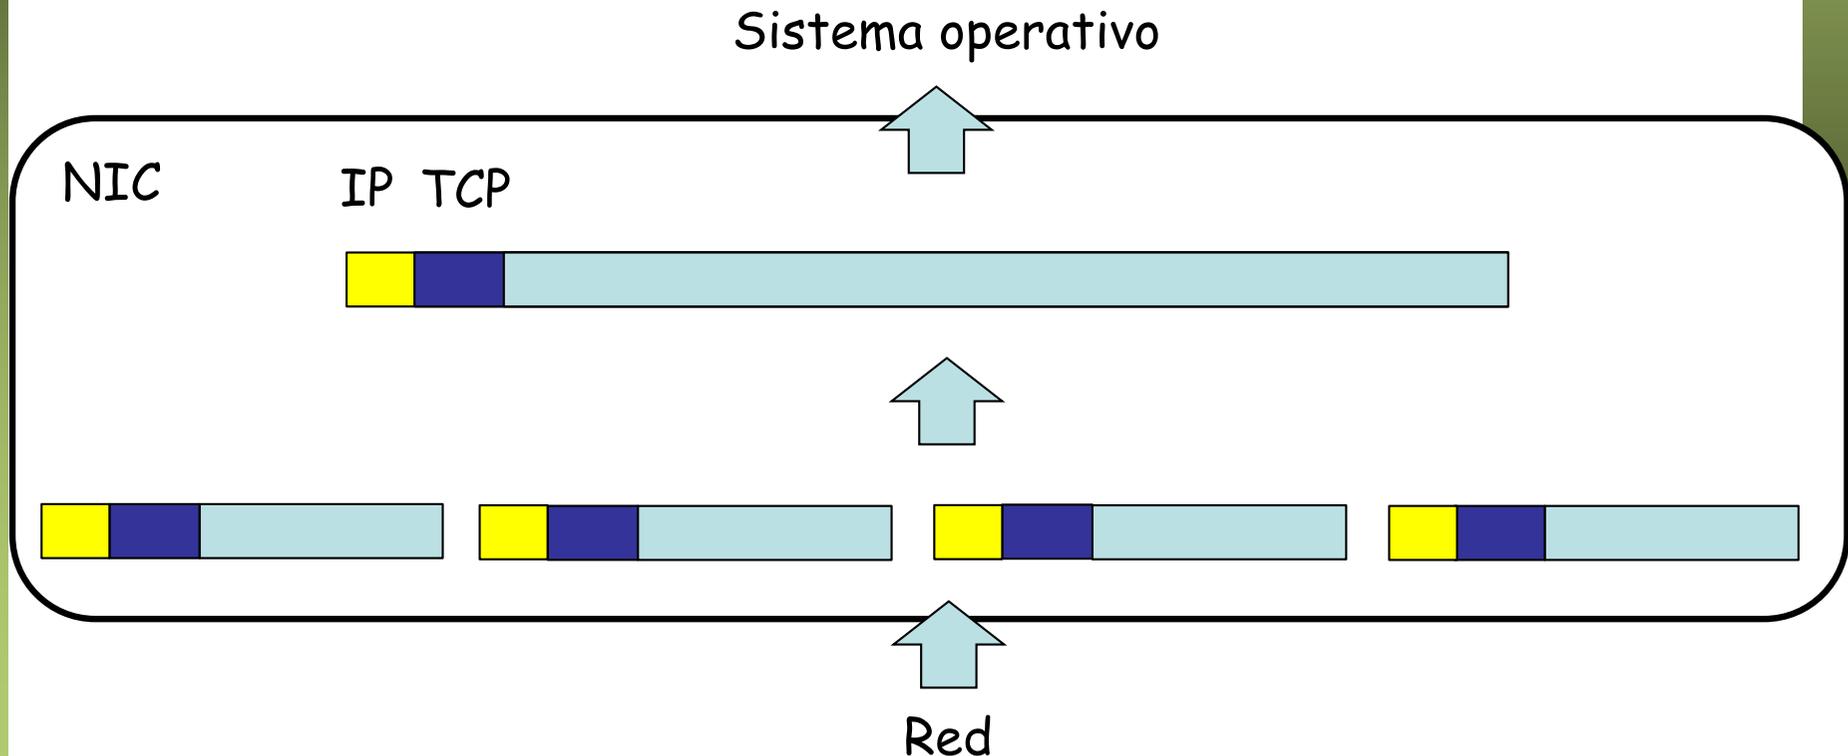
# Jumbo frames

- Diversos estándares han ido aumentando el tamaño máximo de la trama (802.1Q, 802.1ad, MPLS, FCoE, etc)
- A estas últimas en ocasiones se las llama “Baby Giant”
- Jumbo frames suelen estar cerca de los 9 Kbytes (que se puedan transportar bloques de datos de 8Kbytes + encapsulados varios)
- ¿Positivo?
- ¿Negativo?
  - Todos los equipos del camino deben soportarlas
  - Posibles problemas con implementaciones que esperan 1500 bytes
  - Mayores tramas sufren mayor retardo así que no son adecuadas para todos los servicios
  - Mayores tramas pueden llenar antes los buffers de los conmutadores



# LRO

- *Large Receive Offload, Receive Segment Coalescing*
- La NIC une varios segmentos TCP en uno solo
- Crea unas cabeceras TCP e IP para ese nuevo segmento
- Reduce el número de interrupciones y procesamiento de cabeceras en el kernel



# LRO: Ejemplo

The screenshot shows a Wireshark interface with a packet list and a packet details pane. The packet list shows several packets, with packet 26 highlighted. The packet details pane shows the structure of packet 26, including Ethernet II, Internet Protocol Version 4, Transmission Control Protocol, and Transport Layer Security (TLSv1.3 Record Layer).

No.	Time	Source	Destination	tcp.len	frame.len	Info
24	1612366802.319898	192.168.1.3	192.168.1.2	158	224	Application Data
25	1612366802.319977	192.168.1.2	192.168.1.3	0	66	60260 → 443 [ACK] Seq=1077 Ack=29
26	1612366802.320132	192.168.1.3	192.168.1.2	2896	2962	Application Data, Application Data
27	1612366802.320133	192.168.1.3	192.168.1.2	1448	1514	Application Data [TCP segment of
28	1612366802.320191	192.168.1.3	192.168.1.2	944	1010	Application Data
29	1612366802.320193	192.168.1.3	192.168.1.2	2896	2962	Application Data, Application Data
30	1612366802.320194	192.168.1.2	192.168.1.3	0	66	60260 → 443 [ACK] Seq=1077 Ack=50
31	1612366802.320194	192.168.1.2	192.168.1.3	0	66	60260 → 443 [ACK] Seq=1077 Ack=70
32	1612366802.320196	192.168.1.3	192.168.1.2	2392	2458	Application Data, Application Data

▶ Frame 26: 2962 bytes on wire (23696 bits), 2962 bytes captured (23696 bits)

▶ Ethernet II, Src: Universa\_2c:dc:32 (00:1e:37:2c:dc:32), Dst: Universa\_2c:dc:6c (00:1e:37:2c:dc:6c)

▼ Internet Protocol Version 4, Src: 192.168.1.3, Dst: 192.168.1.2

- 0100 .... = Version: 4
- .... 0101 = Header Length: 20 bytes (5)
- ▶ Differentiated Services Field: 0x00 (DSCP: CS0, ECN: Not-ECT)
- Total Length: 2948
- Identification: 0x12b6 (4790)
- ▶ Flags: 0x40, Don't fragment
- Fragment Offset: 0
- Time to Live: 64
- Protocol: TCP (6)
- Header Checksum: 0x9968 [validation disabled]  
[Header checksum status: Unverified]
- Source Address: 192.168.1.3
- Destination Address: 192.168.1.2

▶ Transmission Control Protocol, Src Port: 443, Dst Port: 60260, Seq: 2978, Ack: 1077, Len: 2896

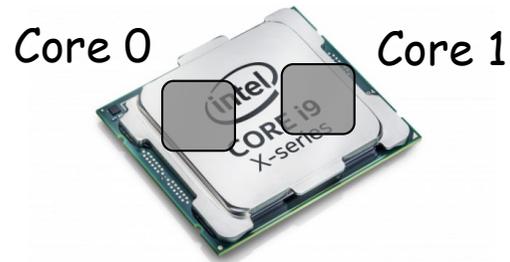
▼ Transport Layer Security

- ▼ TLSv1.3 Record Layer: Application Data Protocol: http-over-tls
  - Opaque Type: Application Data (23)
  - Version: TLS 1.2 (0x0303)
  - Length: 1317

# RSS

- *Receive Side Scaling*
- Multi-CPU o CPU multi-core

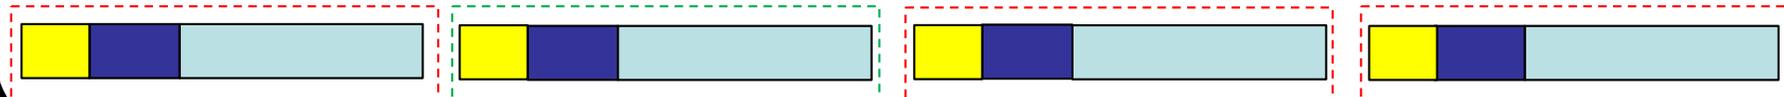
Sistema operativo



NIC

Flujo 1

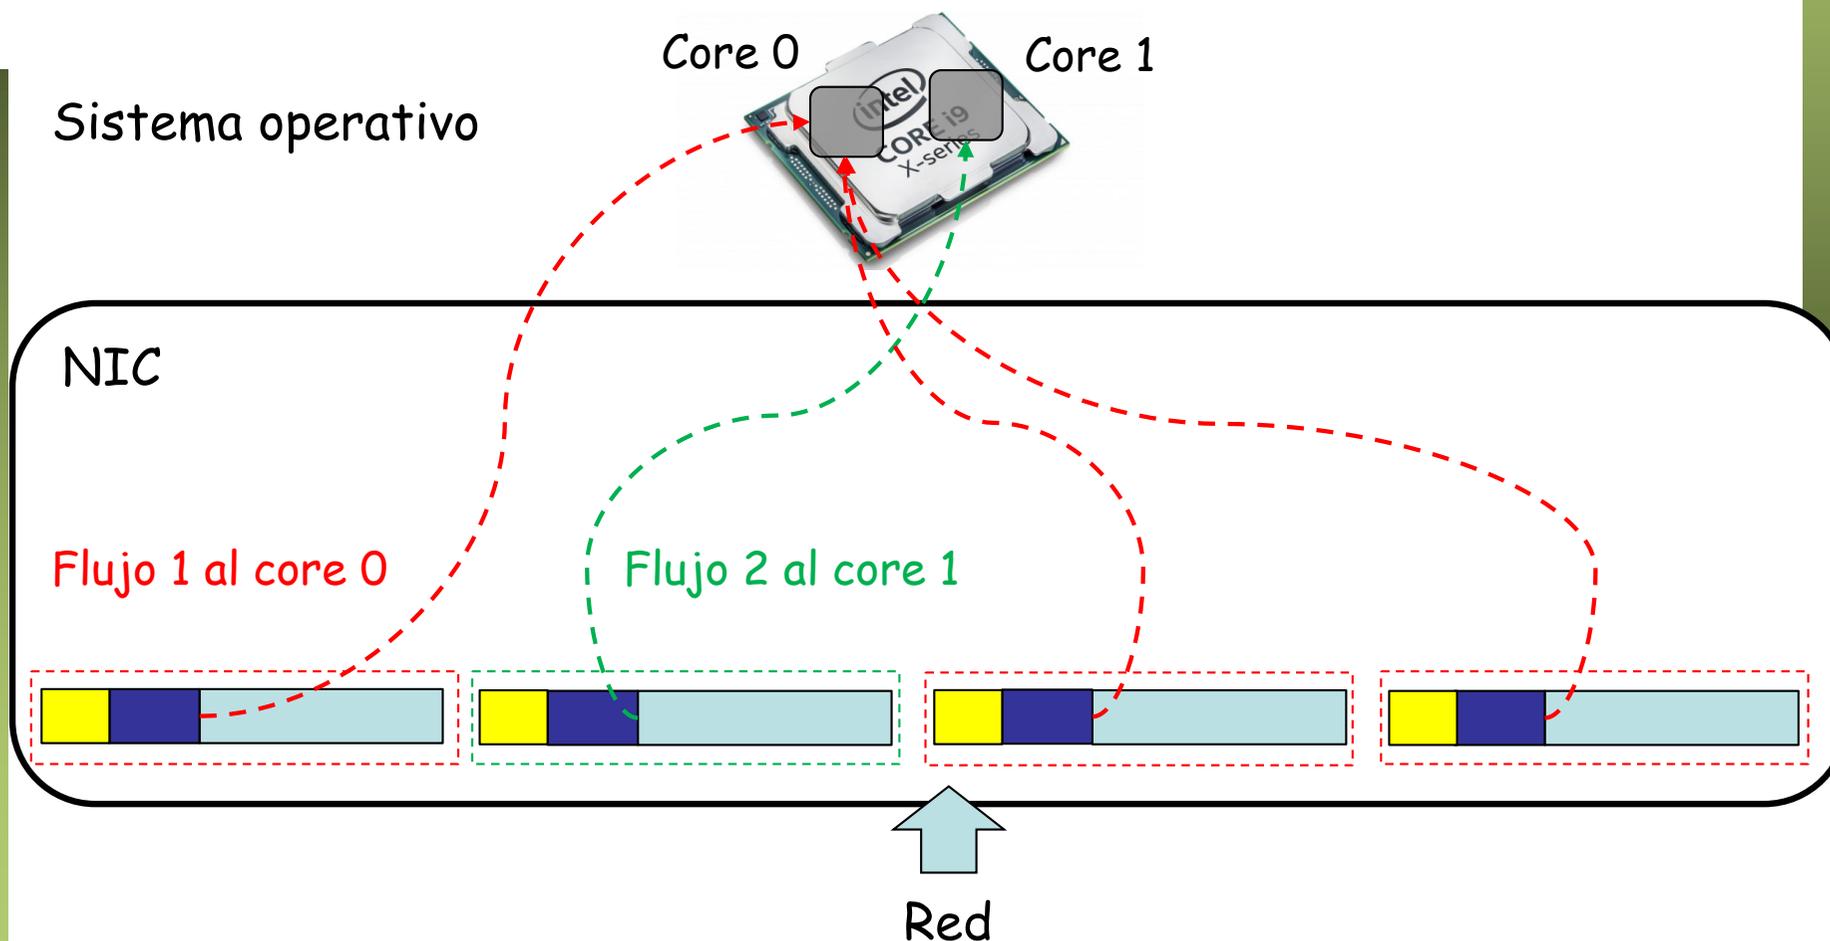
Flujo 2



Red

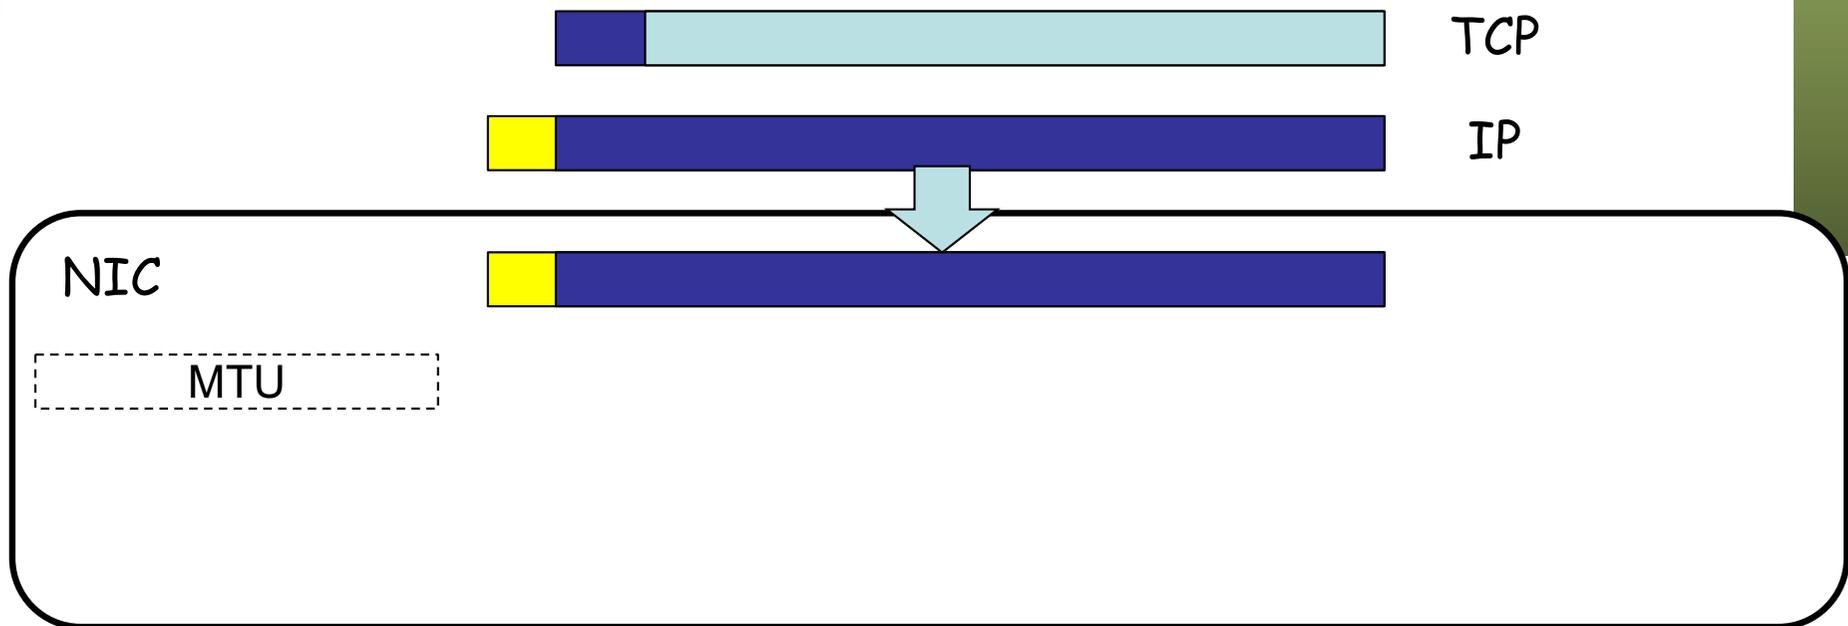
# RSS

- NIC calcula un hash sobre el paquete recibido y con él decide a qué CPU manda la interrupción
- Permite paralelizar entre varias CPUs el procesamiento del tráfico recibido



# LSO

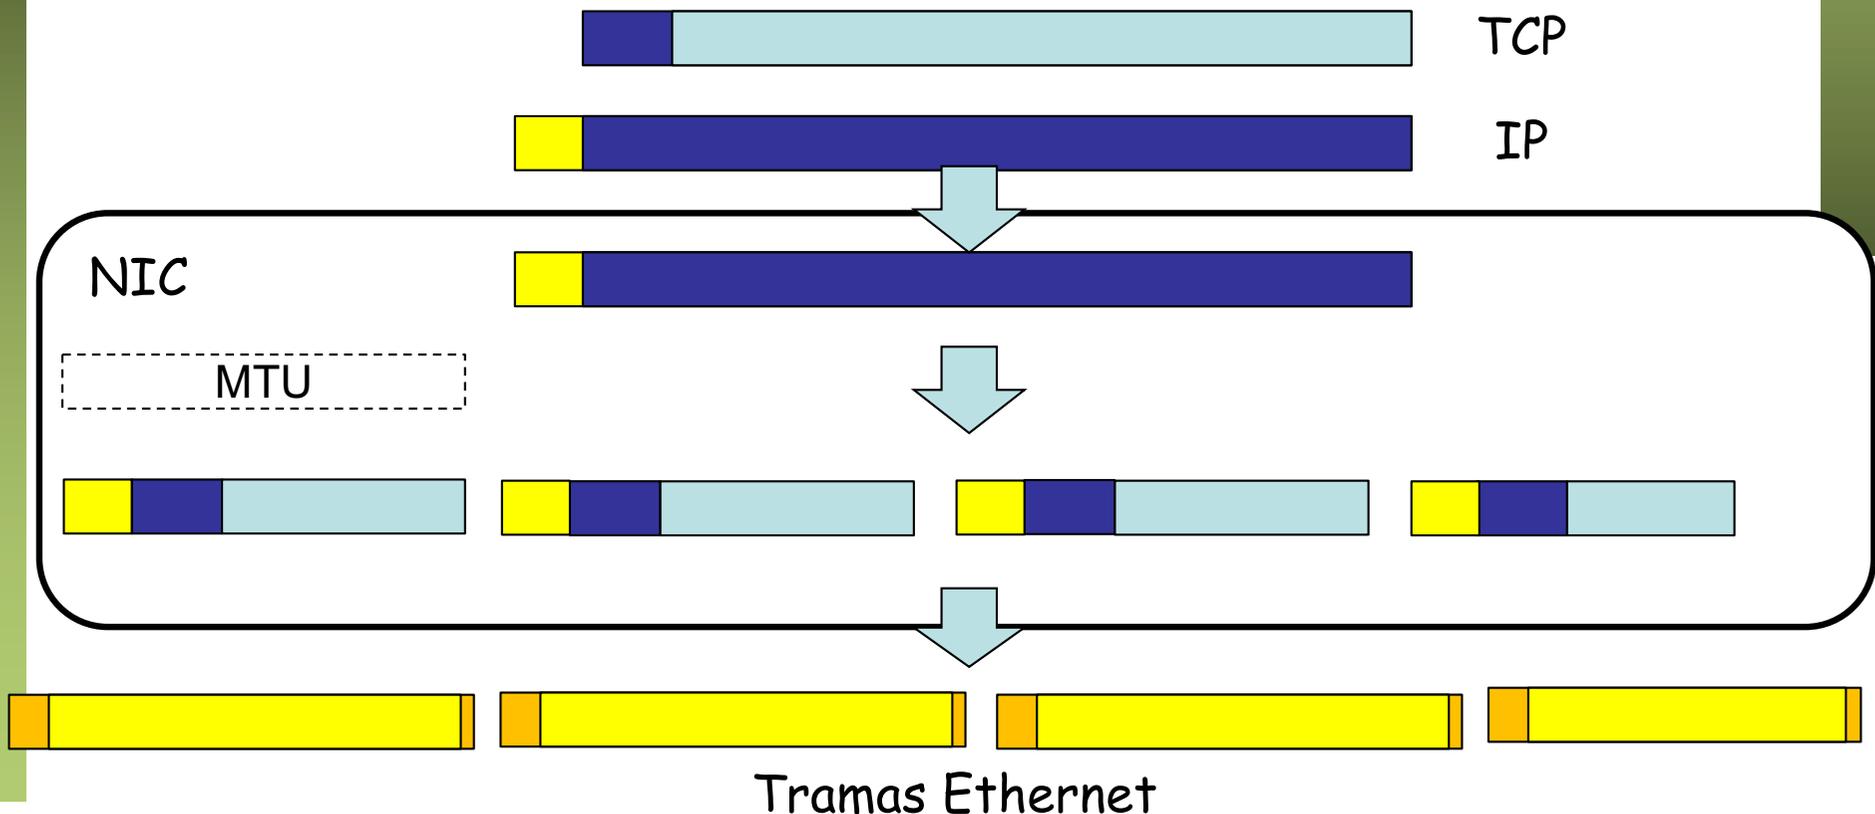
- *Large Segment Offload, TCP Segmentation Offload*
- Busca reducir carga de trabajo a la CPU en transmisión
- TCP entrega a la NIC paquetes más grandes que la MTU
- (...)



Tramas Ethernet

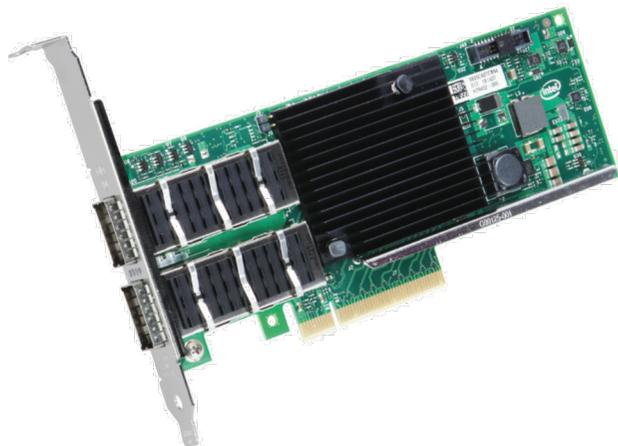
# LSO

- La propia NIC hace la segmentación de nivel TCP
- Eso le obliga a crear nuevas cabeceras TCP e IP, descargando de ello a la CPU
- Requiere que la NIC sepa segmentar el protocolo (solo TCP)
- Problemas con encriptación (IPSec)
- Genera ráfagas de tráfico

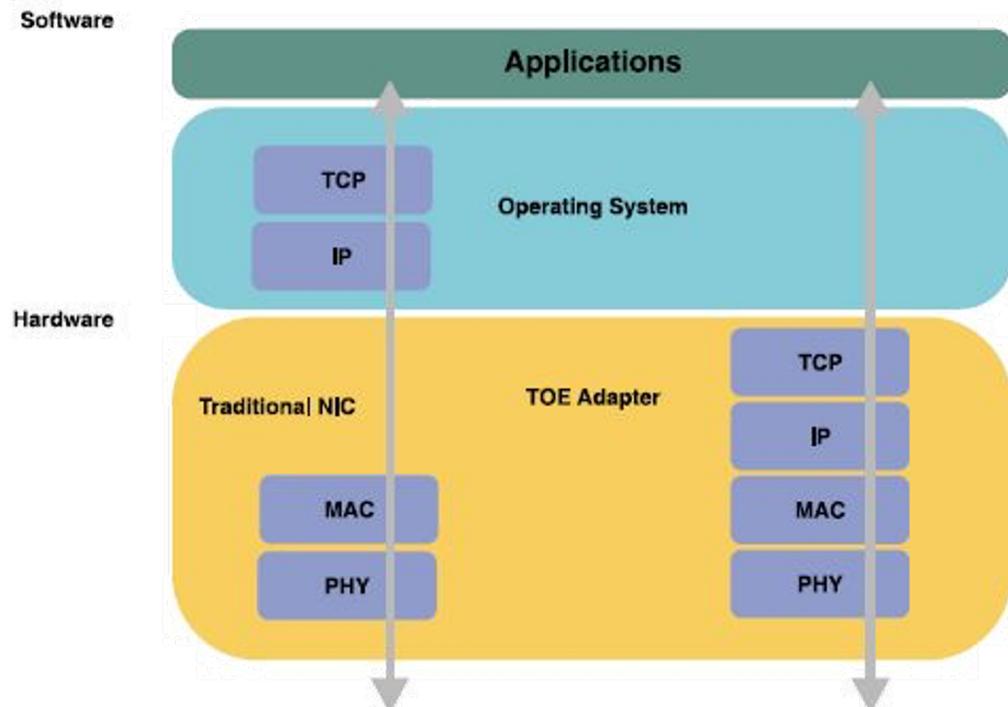


# TOE

- *TCP/IP Offload Engine*
- Los datos pueden pasar directamente de la aplicación a la NIC
- La NIC puede emplearse para todas las tareas de la fase de transferencia y emplear la CPU para el establecimiento y terminación
- O se puede emplear la NIC para todo
- Requiere soporte del sistema operativo

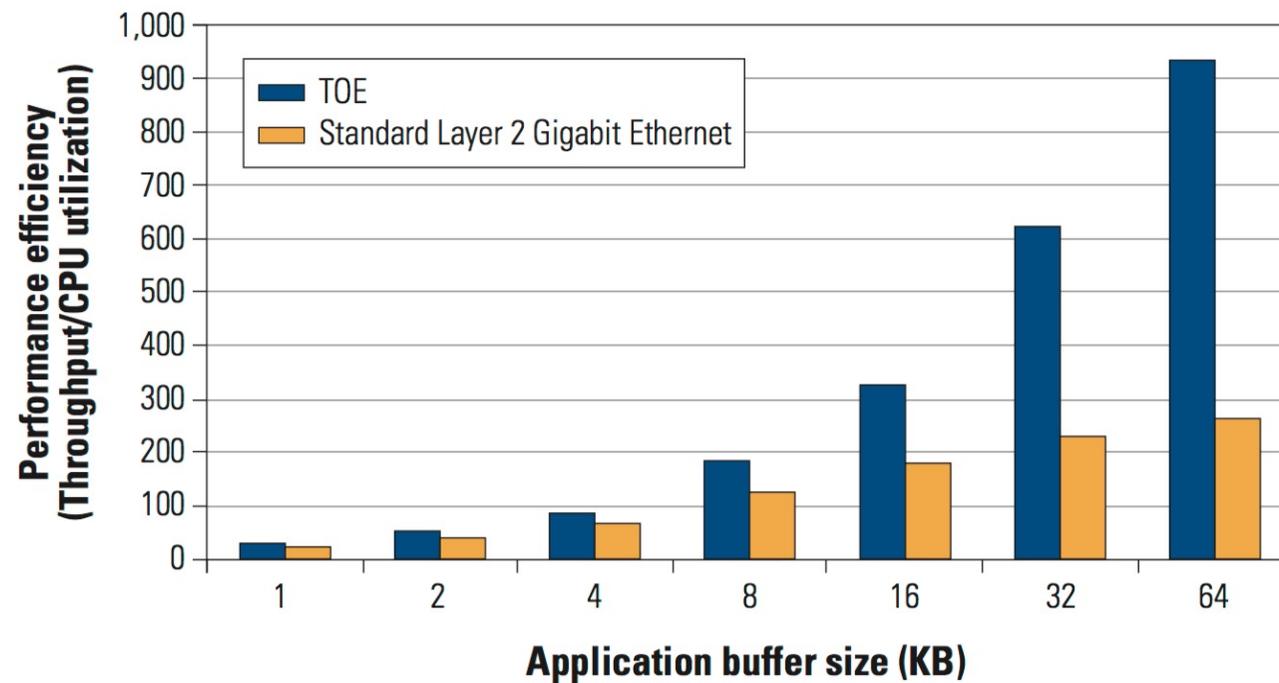


## TCP/IP Offload Engine, TOE



# TOE

- Puede mejorar el throughput
- Reduce la carga sobre la CPU



<http://www.dell.com/downloads/global/power/ps3q06-20060132-Broadcom.pdf>

# Otras funcionalidades

- VMDq, SR-IOV, etc, asociadas a la presencia de máquinas virtuales

